



Применение трендовой компоненты к управлению такой ИНС заключается в том, что ее значения могут быть использованы на этапе обучения рассматриваемой сети в качестве эталонных значений контрольной ошибки, что сократит время обучения и повысит качество создаваемых расписаний.

Исследование проведено при поддержке гранта РФФИ 17-20-01065 «Разработка теории нейросетевого управления железнодорожными транспортными системами».

### Литература

1. Игнатенков, А. В., Ольшанский, А. М. О решении задачи управления искусственной нейронной сетью при квазипериодическом поведении сигнала ошибки / А. В. Игнатенков, А. М. Ольшанский // Перспективные информационные технологии (ПИТ-2016) : тр. Междунар. науч.-техн. конф. / под ред. С. А. Прохорова. – Самара : Изд-во Самар. науч. центра РАН, 2016. – С. 635–638.

2. Игнатенков А. В., Ольшанский А. М. О некоторых путях синтеза управления многослойной ИНС с переменной проводимостью сигнала // Перспективные информационные технологии (ПИТ 2018). – 2018. – С. 816–820.

3. Игнатенков А. В. Нейросетевое моделирование и упорядочение транспортных потоков на линиях железных дорог. Автореферат дис....к.т.н., 05.13.18. - Математическое моделирование, численные методы и комплексы программ. // Пенза, ПензГУ, 2018. – 20 с., с.14.

4. Cleveland R. B. et al. STL: A Seasonal-Trend Decomposition // Journal of Official Statistics. – 1990. – Т. 6. – №. 1. – С. 3-73.

А.В. Пилецкая

## ИСПОЛЬЗОВАНИЕ АФФИННЫХ ПРЕОБРАЗОВАНИЙ ДЛЯ ФОРМИРОВАНИЯ ОБУЧАЮЩЕЙ ВЫБОРКИ ДЛЯ ИСКУССТВЕННОЙ НЕЙРОННОЙ СЕТИ

(Самарский государственный технический университет)

**Введение.** Метод аффинного преобразования обычно используется для коррекции геометрических искажений или деформаций, возникающих при неидеальных углах оптической оси видеокамеры. В докладе аффинные преобразования применяются для формирования дополненного датасета для нейронной сети. Разрабатываемая искусственная нейронная сеть (ИНС) используется при тепловизионном диагностировании радиоэлектронных приборов [1]. На входы ИНС поступают сигналы от встроенных датчиков электрических параметров и термограммы, получаемые с помощью тепловизора. ИНС представляет собой конволюционную сеть для обработки термограмм и однослойную ветвь для обработки измеряемых параметров прибора.



Проблема состоит в том, что, как правило, отсутствует достаточно большое число термограмм неработоспособных состояний для формирования обучающей выборки.

**Формирование дополненного датасета.** На рис. 1 приведен пример множества модельных термограмм для некоторого электронного элемента. Для имитации эффекта зашумленности реальных термограмм в модельные термограммы вносятся искажения границ изотерм. Добавление шума позволило смоделировать ситуацию, когда на исследуемый прибор в момент диагностики действуют какие-либо помехи, мешающие получить четкую термограмму для анализа работоспособности.

Для нейронной сети было взято три класса искусственно зашумленных термограмм с сопоставлением исходных данных. С помощью библиотек Tensorflow, Skillearn, Kerastas и Matplotlib, входящей в программную реализацию, написанную на языке Python, были построены зависимости влияния погрешностей из-за шума на достоверность классификации состояний. На рис 2 представлена зашумленность исходных термограмм с разной степенью искажения.




Рис.1. Модельные термограммы

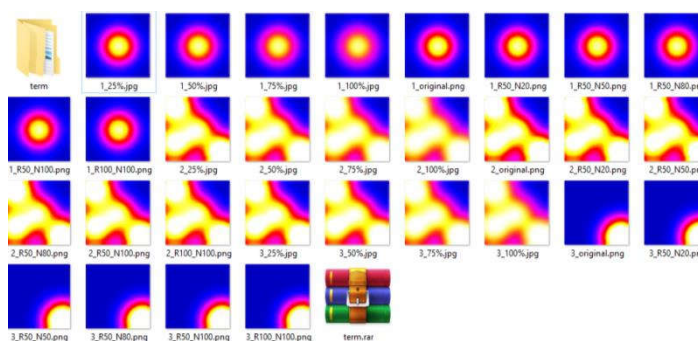


Рис. 2. Зашумленные термограммы



Предположим, что каждый объект характеризуется списком «интересных» точек. В рассматриваемом случае на исходных термограммах было взято 7 точек, которые соответствуют характерным температурам. Если проводить оценку с использованием интервальных арифметических решений, то получим неострое интервальное решение [2]. Понятие нерезкого интервала решения распространено при решении интервальных систем уравнений, но не все полученные решения удовлетворяют поставленной задаче. Интервальное решение считается точным, если оно включает в себя как можно меньше решений. Острота решений, полученных с использованием искусственного интеллекта, зависит от различных факторов. Хорошо известный фактор, который влияет на резкость, - это вхождение заданной интервальной величины в вычисление более одного раза.

Рассмотрим некоторое решение для компонента  $c_{i1}$ ,  $1 \leq i \leq 3$ , [3]:

$$c_{i1} = \frac{v_{i1}}{w_{11}}(u_{11} x_1 + u_{21} x_2 + \dots + u_{m1} x_m) + \frac{v_{i2}}{w_{22}}(u_{12} x_1 + u_{22} x_2 + \dots + u_{m2} x_m) + \frac{v_{i3}}{w_{33}}(u_{13} x_1 + u_{23} x_2 + \dots + u_{m3} x_m) \quad (1)$$

Понятно, что каждое значение  $x_j$  ( $1 \leq j \leq m$ ) входит в вычисления  $c_{i1}$  более одного раза. Чтобы избежать этого, выделяем  $x_j$  и тогда (1) принимает вид [4]:

$$c_{i1} = \sum_{j=1}^m x_j \left( \sum_{k=1}^3 \frac{v_{ik} u_{jk}}{w_{kk}} \right) \quad (2)$$

Выражение (2) реализуется в алгоритме прогнозирования расположения объекта (рис.3). Результаты вычислений приведены на рис. 4.

Таким образом, обучающая выборка для тренировки искусственной нейронной сети выполняется путем отбора проб аффинно-преобразованных «взглядов» на объект диагностики. Это пространство признаков может быть построено путем преобразования известного просмотра контролируемого объекта, предполагая все возможные наборы значений параметров аффинного преобразования [5, 6]. После генерации аффинно-преобразованных представлений, проводится выбор параметров аффинного преобразования из полученных интервальных решений. После этого проверяется условие, чтобы не все сгенерированные представления полностью находились в единичном квадрате (недопустимые представления).

**Заключение.** Датасет, сформированный таким образом, позволяет получить достаточно репрезентативную выборку для обучения нейронной сети. В процессе диагностики проводится дополнение датасета новыми термограммами, получаемыми при обнаружении отказов и неработоспособности контролируемого прибора.



Рис. 3.

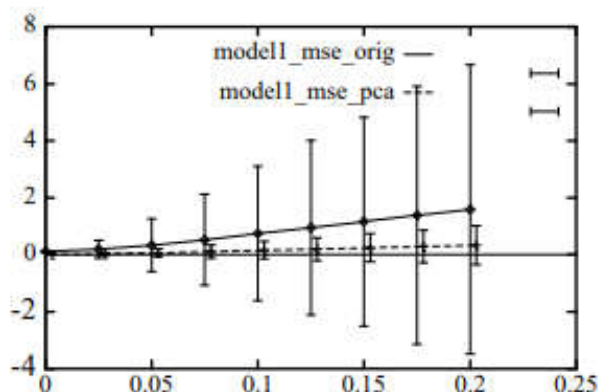


Рис. 4. Вычисление распознавания исходного изображения с аффинным преобразованием

### Литература

1. Орлов С.П. Интеллектуализация информационно-измерительных систем контроля и диагностирования на основе нейросетевых технологий/С.П. Орлов, Р.В. Гирин, О.Ю. Уютова//Мягкие измерения и вычисления. – 2018. - № 4. - С.4-12.
2. Алефельд Г., Херцбергер Ю. Введение в интервальные вычисления. – Москва: Мир, 1987.
3. Голуб Дж., ван Лоун Ч. Матричные вычисления. – Москва: Мир, 1999.
4. Деммель Дж. Вычислительная линейная алгебра. – Москва: Мир, 2001.



5. Лакеев А.В. Существование и единственность алгебраических решений интервальных линейных систем в полной арифметике Каухера// Вычислительные технологии. –1999. – Т. 4, №4. – С. 33–44.

6. Lamdan Y., Schwartz J., Wolfson H. Affine invariant model-based object recognition// IEEE Trans. on Robotics and Automation, vol. 6, no. 5, pp. 578-589, October 1990.

П.К. Попков, С.В. Востокин

## АВТОГЕНЕРАЦИЯ ИСХОДНОГО КОДА НА ОСНОВЕ РЕКУРРЕНТНЫХ НЕЙРОННЫХ СЕТЕЙ

(Самарский университет)

В современном мире все большее количество задач решается посредством использования нейронных сетей. Они стали неотъемлемой частью в автопилотировании автомобиля, распознаванию объектов на изображениях и видеопотоке [1]. Помимо типизированной нейронной сети, которая к слову обладает некоторыми недочетами также существуют рекуррентные нейронные сети LSTM с долгосрочной кратковременной памятью, которые позволяют в своей реализации не просто обучаться на заданном стеке моделей но и обладают памятью, которая способствует обучению долговременным зависимостям.

LSTM разработаны специально, чтобы избежать проблемы долговременной зависимости. Запоминание информации на долгие периоды времени – это их обычное поведение, а не что-то, чему они с трудом пытаются обучиться. Нейронная сеть основана на открытой программной библиотеке для машинного обучения TensorFlow, разработанной компанией Google для решения задач создания и тренировки нейронной сети с целью автоматического нахождения и классификации образов, достигая качества человеческого восприятия.

Используемая рекуррентная нейронная сеть имеет форму цепочки повторяющихся модулей нейронной сети. В обычной рекурсивной нейронной сети RNN, структура одного такого модуля очень проста, например, он может представлять собой один слой с функцией активации гиперболического тангенса и показана на рисунке 1




Рисунок 1 – Структура модуля RNN